Proje Ana Alanı : Yazılım

Proje Tematik Alanı : Yapay Zeka

Proje Adı : Manyetik Rezonans Görüntülerinin Evrişimsel Sinir Ağlarıyla Teşhisi

Özet

Yapay zekâ, hızla gelişim gösteren ve uygulama alanları gün geçtikçe artan bir sektördür. Buna en basit bir robot süpürgeden en karmaşık yüz tanıma sistemleri dahildir. Bu gelişmeler göz önüne alındığında yapay zekânın sağlıkta kullanılıp kullanılamayacağı birçok araştırmaya konu olmuştur. Fakat insan kapasitesinin bile zorlandığı çalışmalarda bilgisayarın kullanılması yakın zamanda mümkün görünmemektedir. Sağlık sektöründe bilgisayara körü körüne güvenilemeyeceği su götürmez bir gerçektir. Bunun için en yüksek doğruluk oranını elde etmenin bu alanda yapılan çalışmalarda hedef konumunda olduğu görülmektedir. Bunun için TCIA (The Cancer Imaging Archive) ve DICOM Archive'nin yanı sıra anonimize edilmiş halka açık veriler de çalışmaya dahil edilmiş ve 9.947 hastanın kontrastlı-kontrastsız T1, T2 ve FLAIR MR görüntüleri teker teker incelenip teşhis edilmiştir.

Bu geniş veri setiyle eğitilen yapay zeka modelleri farklı parametreler hesaplanarak irdelenmiş ve en optimum sonucu elde etme doğrultusunda farklı adımlar izlenmiştir. Sonuçta ortaya çıkan modellerin incelenmesi için bölgemizdeki hastanelerin veri tabanlarında, doktorlar ve hastane yönetimleriyle iş birliği içerisinde, taramalar yapılmış ve yapay zeka algoritması hastanelerin PACS (Picture Archiving and Communication Systems) sunucularında barındırılan yüksek çözünürlüklü taramalar üzerinde çalıştırılmıştır. Görüştüğümüz radyologlar başarım yüzdelerini doğrulamış ve daha detaylı çalışmamız için bizimle fikir teatisinde bulunmuşlardır.

Yaptığımız proje her ne kadar glioma beyin tümörleri ve vücudun çeşitli kemik dokularında gözlemlenebilen fraktür örnekleri üzerinde yoğunlaşmış olsa da uzman doktorlardan alınan görüşler, kullanılan algoritmanın ve yöntemin diğer hastalıkların teşhisinde de başarılı sonuçlar verebileceğini saptamıştır. Ayrıca glioblastoma gibi ölümcül kanser hastalıklarının da erken evredeki görüntüleri bu yazılıma yüklenerek teşhis edilebilir. Bu sonuçlar sektörde çalışan radyologlar tarafından takdirle karşılanmış olup gelecekteki projelere yol gösterici konumdadır.

Anahtar Kelimeler: yapay zekâ, algoritma, YOLOv8, lezyon, MR, sinir ağı

Amaç

Bu projenin temel amacı, sağlık sektöründe yapay zeka teknolojilerinin uygulanabilirliğini tespit etmektir. Bu doğrultuda, projemizde, hasta bilgileri ve görüntüleri, gelişmiş bilgisayar görüntüleme yazılımları kullanılarak işlenmiş ve yapay zeka algoritmaları derin öğrenme algoritmalarıyla eğitilmiştir. Bu eğitimler neticesinde teşhisinde manyetik görüntüleme teknolojilerinin kullanıldığı hastalıklardan Glioma, Meningioma ve Pitiuitary Adenoma'nın teşhisinin başarıyla gerçekleştirildiği saptanmıştır.

Daha önce yapılan benzer projelerin incelenmesi, genellikle son kullanıcının ihtiyaçlarına uygun tasarlanmış uygulamaların eksikliğini ve veri setlerinin yetersizliğinden kaynaklanan düşük doğruluk oranlarını ortaya koymuştur. Bu bağlamda, önceki projeler genellikle spesifik kullanıcı gruplarına odaklanmış ve genel bir uygulanabilirlik eksikliği göstermiştir. Ayrıca, veri setlerinin sınırlı olması, algoritmaların karmaşıklığına rağmen düşük doğruluk oranlarına neden olmuştur. Bu projede ise, geniş bir hasta veri seti kullanılarak elde edilen %98,654 doğruluk oranıyla öne çıkılarak, önceki projelerdeki zayıflıklara karşı güçlü bir çözüm sunulmuştur. Sonuçlar, sektörde çalışan kişileri tatmin edecek düzeyde olmuştur.

Projenin öne çıkan özellikleri arasında, geniş bir hasta veri seti kullanılarak yapay zeka algoritmalarının eğitilmesi ve bu algoritmaların genel uygulanabilirliğinin gösterilmesi bulunmaktadır. Hasta bilgilerinin işlenmesinde kullanılan bilgisayar görüntüleme yazılımları, yüksek çözünürlüklü görüntüler üzerinde etkili bir şekilde çalışarak, tanısal doğruluğu artırmıştır. Elde edilen sonuçlar sektörde çalışan kişileri tatmin edecek düzeyde gerçekleşmiştir.

Giriş

Projenin hedefindeki hastalıkların teşhisi Manyetik Rezonans Görüntüleme (MRG) ve röntgen gibi yöntemlerle elde edilen görüntülerin uzman radyologlar tarafından detaylı bir incelemeye tabî tutulması ile gerçekleştirilmektedir. Örneğin; beyin tümörünün teşhisinde beynin axial, coronal ve sagittal olmak üzere 3 farklı eksende taraması incelenmektedir. En basit bir kırık bile röntgen görüntüleriyle teşhis edilir. Bu durum da eşsiz vakalar için doğruluk oranını düşürmekte ve daha geniş skalada basit bir hastalığın daha karmaşık yollarla yanlış teşhisine yol açabilmektedir.

Bu proje bu alanda YOLOv8 algoritmasının kullanıldığı literatürdeki ilk çalışmadır. Daha önce yapılan çalışmalar incelendiğinde kullanılan veri setlerinin sığlığı ve saha çalışmalarının yetersizliği doğruluk faktörünün hesaplanmasında problemlere yol açmaktadır. Latif vd. (2022) 4.430 görüntü kullanılarak yaptıkları çalışmada SVM (Support Vector Machine) yöntemiyle ortalama %96,19 doğruluk oranı elde edilmiş fakat pratikte yeterliliğini deneyimlememiştir. Anita ve Kumaran (2022) tarafından yapılan bir başka çalışmada beyin tümörlerinin segmentasyonunda yine yüksek bir doğruluk oranı (%98,1) elde edilmesine karşın sadece meningioma üzerinde, saha çalışması yapılmadan bu sonuçlar elde edilmiştir.

Yöntem

Sinir Ağları

Yapay zeka algoritmaları çalıştırılmadan önce oluşturulacak algoritmanın sinir ağları çizilir ve denetlenir. Sinir ağları tıpkı bir insan beyni gibi çalışır. Burada her bir hücre farklı işlemleri yüklenir. Bu hücreler kullanılarak oluşturulan şemalar ise yapay zeka algoritmalarının işlem sistematiğinin anlaşılması bakımından önem arz eder. Basit bir sinir ağının 3 katmanı vardır. Bunlar; Giriş Katmanı, İşlem Katmanı ve Çıktı Katmanı olarak belirlenir.

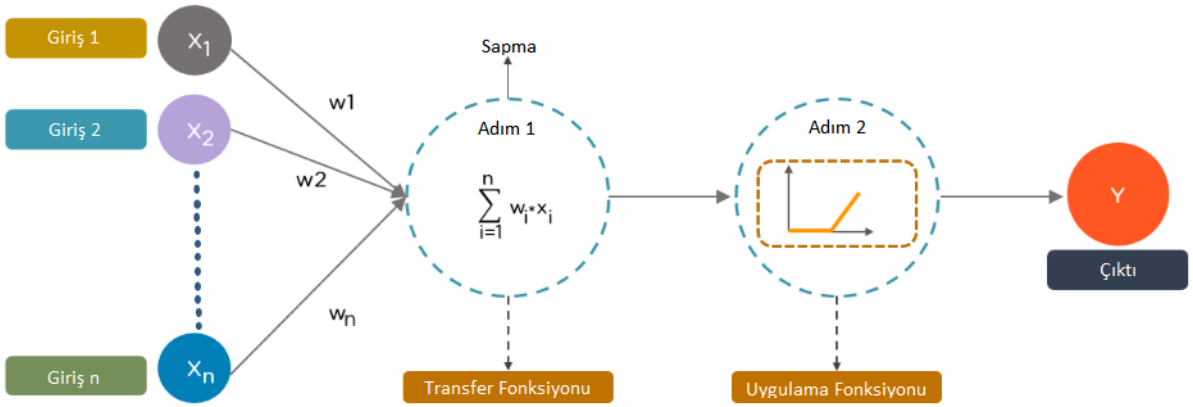

Şekil 1 – Basit bir sinir ağının şeması

Giriş veya girişlerden verilen her bir veri parçasına yük (weight) denir. Bu veri parçaları toplu olarak veya ayrı ayrı işlem katmanına sokulur. İşlem katmanı verinin ön işlem ve düzenleme aşamalarını gerçekleştirir. Daha sonra algoritma bu veriler üzerinde çalıştırılarak kullanıcının yaptırmak istediği işlem yürütülür ve çıktı olarak yazdırılır.

Algoritmanın Çalışma Mantığı

Yapay zekâ alanında çeşitli algoritmalar mevcuttur. Daha önceki projelerde U-Net gibi algoritmalar kabul görmüş olsa dahi bu algoritmaların düşük doğruluk oranları, projemiz için en doğru algoritmanın Ağustos 2023 tarihinde yayımlanan YOLOv8 algoritması olduğu saptanmıştır. Tamamıyla açık kaynaklı olması bu algoritmanın geliştirilebilirliğinin ve çalışma şematiğinin anlaşılması bakımından oldukça önem arz etmektedir. Bu algoritmanın henüz geliştirme aşamasında olması da gelecekte daha yüksek doğruluk oranlarının işlenebileceğini göstermektedir.

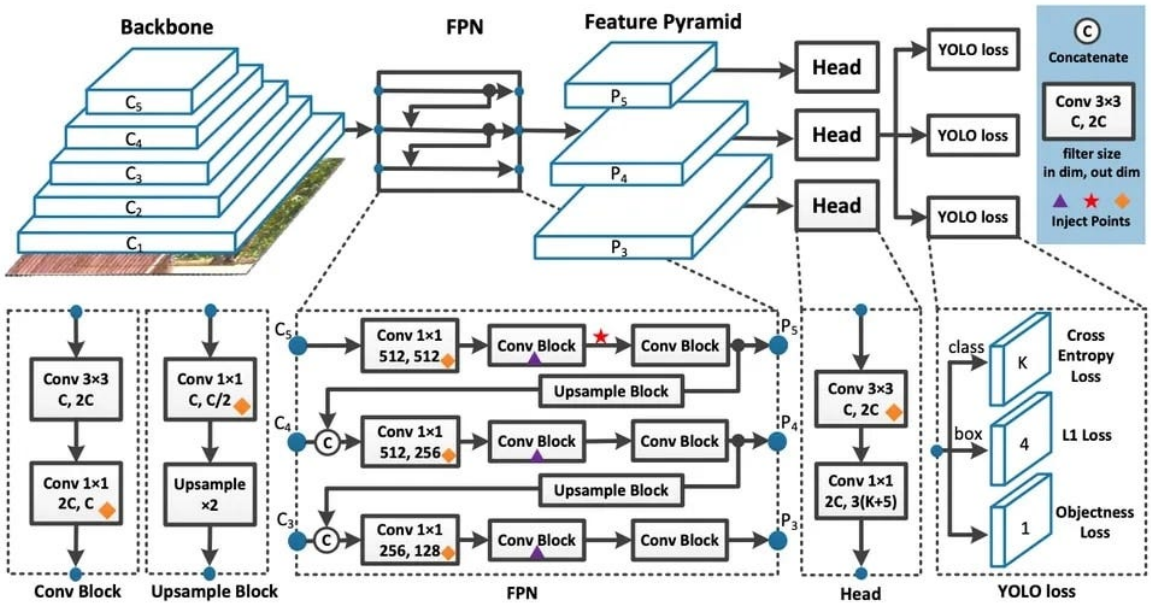

Şekil 2 – YOLOv8 algoritmasının çalışma şematiği

Yapay zekâ algoritmalarının tahmin sistemleri, görüntüleri farklı boyutlarda ve kontrast düzeylerinde işleyerek dönüşüm bloklarından elde ettiği çoklanmış verileri model dosyasına kaydeder. Bir "epoch" yani dönüm neticesinde elde edilen model; doğrulama ve test görselleri kullanılarak eğrik hesaplamalara tabi tutulur. Bu hesaplamalar sonucunda her görüntü belli ızgaralara bölünür. Sonuçlar farklı bilgi işlem algoritmalarından geçirilerek son kullanıcının idrak edebileceği yüzdelik rakamlara dönüştürülür. Etiketleme işlemi sonucunda kaydedilen koordinatlar kartezyen sistemde görsel üzerine bir katman olarak eklenir. Alan formülleri kullanılarak bu katmanın görselin üzerinde belirlenen ızgaraya göre durumları hesaplanır.

Görüntünün çözünürlüğü, bit derinliği ve renk skalası gibi faktörleri değiştirilerek yapay zekânın aynı görüntüyü farklı koşullar altında işlemesine olanak tanınır. Bu katmanlara ek olarak kullanıcı tarafından yapay zekaya girilecek veriler farklı katmanlara ve boyutlara ayrılarak yahut fonksiyonel dönüşümlere tabi tutularak ek işlem piramitleriyle yapay zekanın doğruluğu artırılabilir. Farklı kontrast ve parlaklık düzeylerinin işlenmesi Manyetik Rezonans görüntülerin yapay zeka tarafından tanımlanabilmesi için fazlasıyla önemlidir. Bunun için işleyeceğimiz görüntüleri YOLOv8 algoritmasının işlem katmanlarına ek olarak harici parlaklık ve kontrast çoklama katmanlarına tabi tutmak doğruluk oranlarını fark edilecek ölçütte artıracaktır. Bunun için girilen ham görüntü Python'da kullanılan PIL (Python Image Library) kütüphanesi kullanarak farklı değerlerde dönüşümlere tabi tutulmuştur. Bu dönüşüm görüntülerin parlaklık katmanlarında gerçekleştirilen ±%16 oranlı bir parlaklık değişimiyle yapılmıştır. Buna göre her bir görüntü 3 kopyaya ayrılmış ve bunların 1'i asıl görüntünün bir kopyası iken diğer ikisi parlaklık katmanının iki yönlü değişimi ile oluşturulur.

$$Doğruluk\ Oranı = \frac{(TP + TN)}{(TP + FP + TN + FN)}$$

YOLOv8'in sınıflandırma algoritmasının doğruluk oranı yukarıdaki formüle göre hesaplanır. Burada TP (True Positive), TN (True Negative), FP (False Positive), FN (False Negative) olmak üzere 4 farklı değişken mevcuttur. Bu değişkenler çalışma şematiğinde belirtilen ızgara üzerine çizilen poligonların birbirlerine olan oranından ibarettir. Bu oranlar yapay zekânın elde ettiği eşleşme koordinatlarıyla çizilen çokgenler, bu eşleşmeyi elde etmek için çizdiği çokgenler ve kullanıcı tarafından etiketleme için kullanılan çokgenlerin alanlarının oranlarıyla hesaplanır.

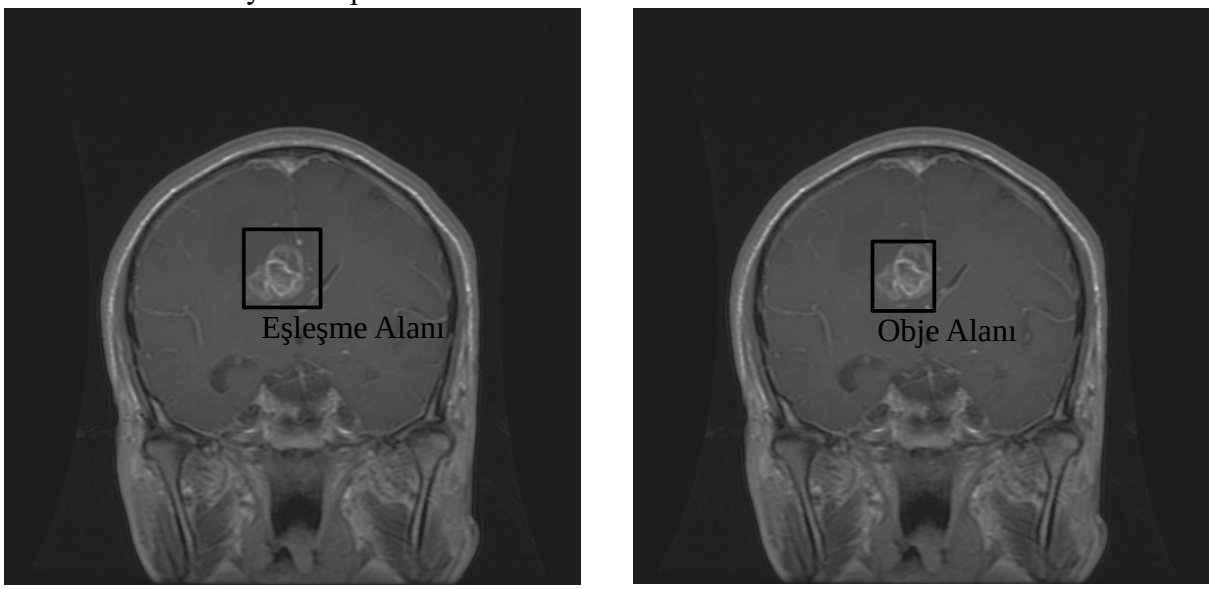

Şekil 3 – Eşleşme Alanı ve Obje Alanı'nın tanımı

$$IoU\left(\text{Intersection Over Union}\right) = \frac{Eşleşme\ Alanı \cap Obje\ Alanı}{Eşleşme\ Alanı \cup Obje\ Alanı}$$

IoU (Intersection Over Union), doğruluğun yorumlanması için çok önemlidir. Örneğin kullanıcı tarafından A(17, 9), B(17, 5), C(13, 9), D(13, 5) noktalarıyla etiketlenen bir ABCD cismi yapay zeka tarafından K(15, 8), L(15, 6), M(11, 8), N(11, 6) noktalarında tespit edilirse $\frac{Alan(ABCD \cap KLMN)}{Alan(ABCD \cup KLMN)} = \frac{1}{6} = \%\,16{,}66$ olur. Bu görüntü ile kullanıcı etiketi arasındaki eşleşmenin oranıdır. Genellikle IoU > %50 olan değerler geçerli çıktı olarak kabul edilir. IoU doğru eşleşmenin olup olmadığını kontrol etmek için sınır orandır. Bu yalnızca görüntü ile yapay zeka arasında eşleşmenin doğru olup olmadığını hesaplamamızı sağlar. Sınıflandırma modellerinde doğruluk oranları IoU üzerinden hesaplanırken konumlandırma işlevli algoritmalarda bu formüller yerine mAP (mean Average Precision) bulunur. Bu modellerin doğruluk oranı hesaplamalarında bir standart gibidir.

$$mAP = \frac{1}{n}\sum_{k=1}^{k=n} AP_k$$

mAP (mean Average Precision) yani genel ortalama hassasiyet, modelin tanıdığı her bir biçem için ortalama ölçüm hassasiyetini yani genel doğruluk oranını bize verir. Burada n, biçim sayısı; k, biçim sırası ve AP_k, yalnız k sıralı modelin ortalama hassasiyetini verir. AP_k, yapay zekanın hassasiyet-çağrışım grafiğinin altındaki alan hesaplanarak bulunur. Bu grafiği yapay zeka her görüntü için teker teker farklı hesaplamalar yaparak çıkarmaktadır. Çıktı grafiği incelediğimizde konumlandırma modelinin doğruluk oranını gözlemlemiş oluyoruz.

Verilerin Toplanması

Veri toplama sürecinde yapılan değerlendirmeler yapay zekâ algoritmasının doğruluğunu etkileyen en önemli faktörlerden biridir. Bu kapsamda yapılan kaynak taramalarında bilimsel çalışmalarla temellendirilmiş veri havuzları esas alınmıştır. Bu projede alanında uzmanlaşmış kişilerin yardımıyla farklı durumlar ve eşsiz vakalar birer birer incelenmiş ve kullanılan veri havuzu en doğru sonuçları verecek şekilde daraltılmıştır. Bu da algoritmanın daha doğru sonuçlar üretmesinde başlıca etmen olmuştur. Bu doğrultuda hasta bilgileri ve görüntüleri bilgisayar görüntüleme yazılımları kullanılarak işlenmiş ve algoritma bu doğrultuda eğitilmiştir. Projemiz %98,654 doğruluk oranıyla ön plana çıkmaktadır.

Doğru teşhis yüksek bilgi birikimi ve uzun mesai gerektirir. Gelişen bilgi işlem teknolojileri sayesinde çizilen yapay sinir ağları kullanılarak bilgisayarı radyologların yaptığı işi daha yüksek doğruluk oranıyla daha kısa sürede gerçekleştirmesi için eğitebiliriz. Bu projenin amacı da farklı organlar üzerinde farklı tarama ve teşhis yöntemleriyle tespit edilen hastalıkların yapay zeka teknolojileriyle pratikte uygulanabilirliğini tespit etmektir. Bu çerçevede gerçekleştirilen gözlemlerde YOLOv8 (You Only Look Once) algoritmasının kullanılması öngörülmektedir ve veriler bu algoritmanın kapasitesine uygun toplanmıştır

Kullanılacak verilerin alanında uzman kişilerden onay alması ve eğitimde kullanılabilirliğinin güç olmaması elzemdir. Başta özel hastaneler olmak üzere yaptığımız çalışmada MR görüntülerin ne formatta ve hangi sıklıkta olduğu gözlemlenmiştir. Prof. Dr. Ertuğrul MAVİLİ ve Uzm. Dr. Suzan TUNÇ ÇEKİM ile yapılan görüşmelerde verilerin sınıflandırmasının teşhis başlıklarına göre yapılması gerektiği anlaşılmıştır. Sonuçta beyin tümörleri için verilerin Glioma, Meningioma ve Pituitary Adenoma olmak üzere 3 ana hastalık türü altında toplanıp işlenmesi uygun görülmüştür.

Teşhis/Verinin Niteliği	Adedi	Çözünürlüğü	Bit Derinliği
Glioma	2.907	512x512 (piksel)	8bpp (piksel başına bit)
Meningioma	2.353	512x512 (piksel)	8bpp (piksel başına bit)
Pituitary Adenoma	2.687	512x512 (piksel)	8bpp (piksel başına bit)

Şekil 4 – Kullanılan veri setinin nitelikleri

Siemens Magnetom Avanto 1.5 Tesla MR cihazı kullanılarak çekilen örnek bir MR görüntüsünün DICOM formatında 512x512x8bpp çözünürlükte olduğu tespit edilmiştir. Sonuç olarak toplanan verilerin çözünürlüğünün alt sınırı olarak 512x512x8bpp belirlenmiştir. Bunun altında olan 19.671 MR görüntüsü projenin veri havuzundan çıkarılmış ve optimum sonucun elde edilmesi için yapay zekaya girilen verilerin birbirleriyle aynı nitelikte olmasına dikkat edilmiştir. Genel ağ ortamından edinilen .mat (MATLAB file) formatındaki dosyalar basit bir dönüştürme betiğiyle yapay zekanın algılayabileceği bir format olan .png (Portable Network Graphics) formatına dönüştürülmüştür. Bu parametreler en yüksek çözünürlüğü ve doğruluk oranını çıktı olarak almak için değerlendirilmiştir.

Veri toplama, KVKK'ye uyularak gerçekleştirilmesi gereken bir işlemdir. Bu durum için gerekli izinlerin alınması projenin çalışma zamanını etkileyeceğinden verilerin anonimize edilmiş herkese açık kaynaklardan toplanmasına karar verilmiştir. Bu kapsamda TCIA, DICOM Library ve bilimsel araştırmalardan toplanan veriler teşhis edilmiştir. Veriler toplanırken geçerliliği ve doğruluğu radyologlarca saptanmış setler havuza eklenmiştir. Buna göre beyin alanında 9.947 farklı görüntü incelenmiş ve bunlardan 2.907'si Glioma, 2.353'ü Meningioma, 2.687'si Pituitary Adenoma olarak teşhis edilmiştir. Kalan 2.000 görüntünün tamamının sağlıklı hastalardan görüntülendiği saptanmıştır.

Verilerin Etiketlenmesi

Algoritmaya girilen verilerin etiketlenmesi uzun mesai gerektiren bir işlemdir. Bunun için çeşitli yazılımlar mevcuttur fakat bu yazılımlar bizim hedef kümemiz olan manyetik rezonans görüntülerinin işlenmesi için optimize edilmiş durumda değiller. Bu proje için geliştirilen MART programı kullanılarak tümörlerin yeri ve konumu etiketlenmiştir.

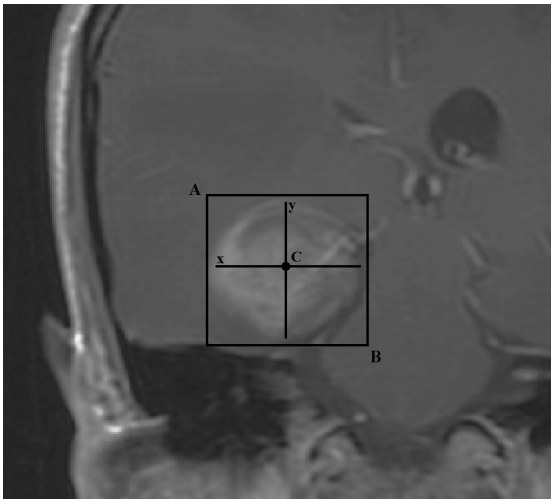

Şekil 5 – Etiketleme sisteminin kartezyen sistemde gösterimi

Seçilen görüntülerin etiketlenmesi aşamasında kullanıcı arayüzünün etkileşimli çizim fonksiyonlarıyla lezyon görülen bölge işaretlenir. Kullanıcı tarafından arayüz yazılımında çizilen poligonun ağırlık merkezi (C) bulunur. Bu nokta ile kullanıcı tarafından çizilen poligonun kenarlarının orta noktaları arasına bir doğru çizilir ve bu doğrunun iki uçlu uzunuluğu hesaplanır. Örneğin; $A(x_1, y_1), B(x_2, y_2)$ noktaları ile çizilen bir dikdörtgenin orta noktası:

$$C=(\frac{x_1+x_2}{2},\frac{y_1+y_2}{2})$$

formülüyle bulunur. x, y uzaklıkları d_x, d_y ise:

$$d_a=|a_1-a_2|$$

ile bulunur. Daha sonra bulunan bu değerler “labels” klasöründe her görsel için dosyanın kendi adıyla .txt uzantılı dosyalar olarak kaydedilir. Etiket dosyalarının formatı her satır için önce biçim sırası olmak üzere görsel üzerinde birimkarelik skalada orta noktanın koordinatı ve sırasıyla x, y uzaklıklarıdır.

Toplanan setlerin tamamının aynı formatta ve çözünürlükte olması algoritmanın işlem süresini kısaltmak ve işlem doğruluğunu artırmak için önemlidir. Bunun için çeşitli kullanıcı etkileşimli etiketleme yazılımları mevcuttur fakat bu yazılımlar MR, röntgen gibi görüntüleme sistemleriyle doğrudan uyumlu olarak çalışmamaktadır. Kullanımı ve yazımı kolay olduğu için Python dilinde bu proje için MART adında bir program yazılmıştır. Görüntü işlem kütüphanelerinin içerdiği fonksiyonlar kullanılarak arayüz MART’a görüntüleri 640x640x8bpp olarak yeniden boyutlandıran betik eklendi. Ayrıca farklı parlaklık düzeylerinin bilgisayar tarafından tanınabilmesi için arayüz yazılımına eklenen parlaklık filtresi, farklı MR cihazları ile yaptığımız çalışma arasında meydana gelebilecek uyumsuzlukları da ortadan kaldırmış oldu. MART yazılımı Python dilinde Ultralytics kütüphanesi temelinde yapay zeka işlevlerini yerine getirir. MART yazılımının kaynak kodları E-BİDEB sisteminde “EK BELGELER” sekmesine yüklenmiştir.

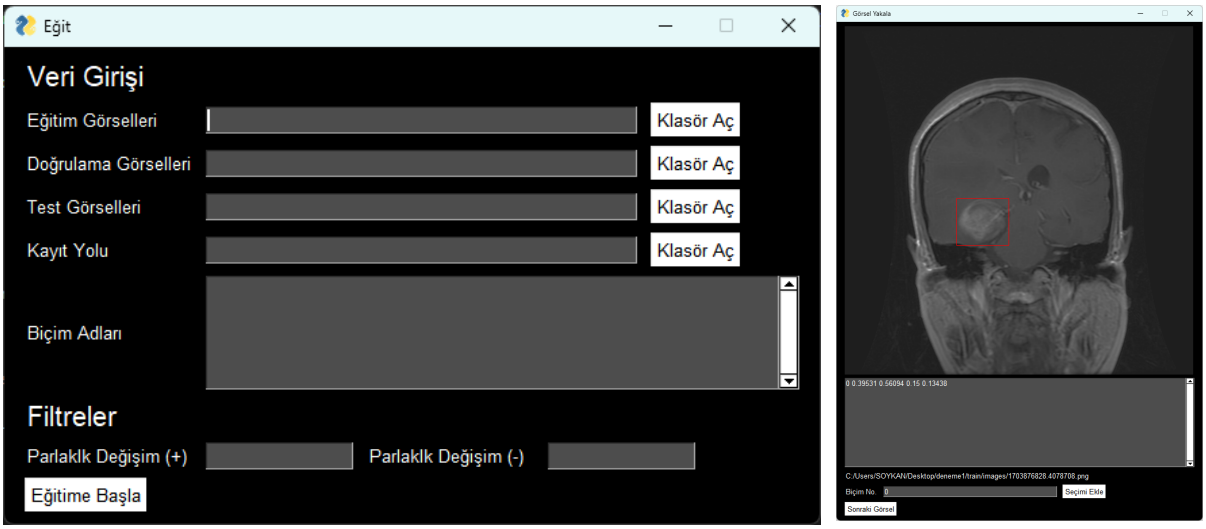

Şekil 6 – MART yazılımının veri işlem arayüzü

Eğitim arayüzünde "Veri Girişi" ve "Filtreler" olmak üzere 2 başlık mevcuttur. Veri Girişi başlığının altında eğitim, doğrulama ve test görsellerinin seçimi; Kayıt Yolu için etiketlenen görüntülerin ve etiketlerin dışa aktarılacağı konum; Biçim Adları için her satıra birer sabit olmak üzere veri başlıkları girilir. Filtreler bölümünde farklı tarama cihazları ve özel vakalar ile yapay zekâ modeli arasında uyumsuzluk oluşmaması adına görüntü, girilen parlaklık değişim değerlerine göre 3 kopyaya ayrılır. Bu kopyalardan 1'i girilen görüntün aslı olup diğer ikisi parlaklığın girilen değerlere göre artırılmış ve azaltılmış kopyasıdır. "Eğitime Başla" tıklandığında son kullanıcının Görsel Yakala penceresinde sırayla akan görüntülerin lezyon barındıran bölgelerini kutucuk içine alıp tümörün türünü teşhis etmesi istenir.

Görsel Yakala arayüzünde lezyon barındıran görselin görüntülendiği bölge ve bunun altında kutucuk koordinatlarının ve etiketin barındırıldığı çok satırlı görüntüleme bölümü mevcuttur. Bunun altında görüntünün diskteki yolu ve önceki pencerede girilen Biçim Adları'nın ilk satırı 0'dan başlamak kaydıyla Biçim No. girilir. Bütün bunlar girildikten sonra "Seçimi Ekle" tıklanır ve eğer görüntüde yapılacak işaretlemeler tamamlandıysa "Sonraki Görsel" tıklanarak devam edilir. Eğer görüntüde lezyon tespit edilemediyse pencere kapatılır ve görüntü veri havuzuna eklenmez. Görsel Yakala penceresi her görüntü için 3 kopyayı etiketleriyle birlikte önce farklı parlaklık-renk düzeylerinde kaydeder.

Şekil 7 – Segmentasyon örnekleri

Roboflow'da lezyon tespit edilen bölgeler Şekil 6'da görüldüğü gibi farklı tanımlama sistemleri için teker teker işaretlenmiştir. Bu işlem uzman radyologlar gözetiminde yapılmış olup teşhis edilen görseller veri setine eklenmiştir.

Tümör Sınıflandırma Modelinin Eğitimi

Şekil 8 – YOLOv8 segmentasyon sistemleri

Sınıflandırma modelinin diğer modellerden temel farkı segmentasyon işleminin doğrudan olmamasıdır. Bu modelde kullanıcıya verilen çıktılar yalnızca eşleşme oranıdır. Eğitim aşamasında algılama ve segmentasyondan farklı olarak bu modelde etiketleme işlemine gerek duyulmaz. Bunun için sınıflandırma modeli beynin belli bir bölgesindeki görünür lezyonları değil, tüm görüntüdeki değişimi ve farklılıkları gözlemler. Burada konumlandırma modeli önce MART daha sonra segmentasyon için Roboflow'da eğitilmiştir. Neticede beyin tümörlerinin yerini başarılı bir şekilde tespit etmek hedeftir.

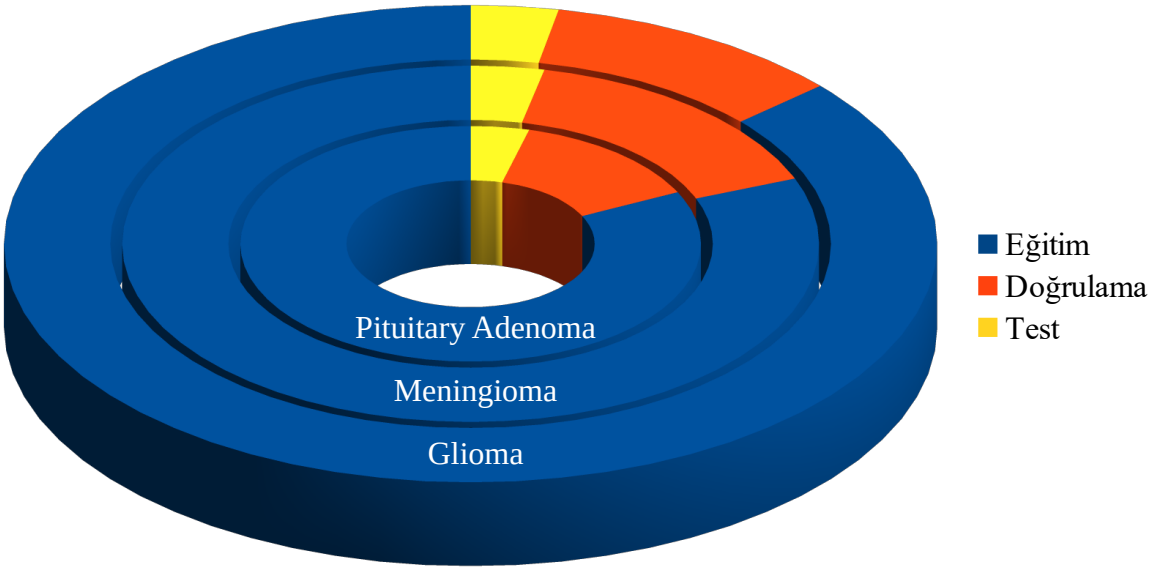

Şekil 9 – Kullanılan görüntülerin işlem aşamalarına göre dağılım grafiği

Bu modelde yapay zekâya girilen 2.907 glioma görüntüsünün 2.515'i eğitim, 304'ü doğrulama ve 88'i test; 2.353 meningioma görüntüsünün 1.905'i eğitim, 368'i doğrulama, 80'i test; 2.687 pituitary adenoma görüntüsünün 2.209'u eğitim, 368'i doğrulama, 110'u test olarak sınıflandırılmıştır. Yapay zeka modeli oluşturulurken her 8 örnekte bir yenileme ve 15 tekrar oranlarıyla çalıştırılmıştır. Bu rakamlar en yüksek teşhis doğruluğunu elde etmek için optimum oranda belirlenmiştir.

Eğitim işlemi AMD Ryzen 5 5500U with Radeon Graphics, 2100 Mhz, 6 Çekirdek, 12 Mantıksal İşlemci ve 8,00 GB fiziksel bellek üzerinde gerçekleştirilmiş ve yukarıdaki değerlerle 4 saat 12 dakikada 1.02 it/s hızla gerçekleşmiştir. Ayrık yapay zekâ modülü olan bir FPGA ya da Görüntü İşlem Birimi kullanılarak bu süreler saniyelere kadar indirilebilmektedir. Eğitim süresinin kısa tutulması için "epoch" yani tekrar oranı ya da dönüm sayısı 15 gibi düşük bir rakamda tutulmuştur. Modelin çalışma süresinin kısa tutulması için baz model "yolov8n" olarak seçilmiştir.

Tümör Konumlandırma Modelinin Eğitimi

Konumlandırma modelinin sınıflandırma modeline göre farkı görüntüyü istenilen katman içerisinde işleyerek lezyonun tespit edildiği bölge hakkında doktora bilgi verebilmesidir. Bu erken teşhis aşamasında insan gözüyle görmesi zor olan bölgelerde hastalık oluşumunu erkenden tanımlayıp yapay zekanın hastalıklar ilerlemeden tanı koymasına olanak sağlayabilir. Konumlandırma modelinin bir diğer özelliği ise kullanıcı tarafından tarama fonksiyonuna girilen görüntülerin genel çerçevede değil bölge bölge ayrılarak incelenmesidir. Bu sayede daha olası teşhis sonuçları elde edilebilir.

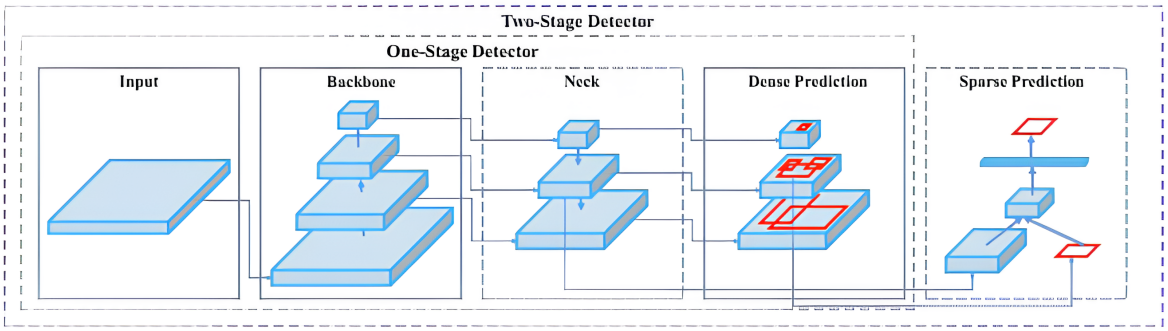

Şekil 10 – Konumlandırma modelinin işlem şeması

Algoritmanın temelinde, kutucukların olası konumlarını belirleme sürecinde ortalama değerleri kullanarak rastgele eşleştirmeleri karşılaştıran bir yaklaşım benimsemesi bulunmaktadır. Bu, nesne tespiti sürecinde daha hassas sonuçlar elde edilmesini sağlar ve kullanıcılara belirli nesnelerin konumları konusunda daha güvenilir bilgi sunar. Ortalama değerlere dayalı konvansiyonel yöntemler, özellikle karmaşık ve yoğun sahnelerde başarısız olabilirken, YOLOv8'in eşleştirme odaklı yaklaşımı, çeşitli vakalarda daha güçlü bir performans sergiler. Bu, sınırlı hesaplama kaynaklarına sahip sistemlerde bile etkileyici sonuçlar elde etme yeteneğini beraberinde getirir. Bu, gerçek zamanlı uygulamalarda ve donanım kısıtlamalarına tabi ortamlarda bile kullanıcıların ihtiyaçlarına uygun çözümler sunma potansiyelini arttırır.

Konumlandırma modelinin eğitiminde hem segmentasyon hem de algılama sistemleri kullanılmıştır. Roboflow üzerinde lezyon görüntülenen bölgeler tespit edilerek poligonal şekillerle tümörün tam olarak şekli katmanlandırılmıştır. Algılama sisteminde sadece kutucuklarla sınırlı kalınmıştır. Sonuç olarak iki sistemde de aynı görüntü verileri kullanılmıştır.

Konumlandırma modelinin eğitiminde yapay zekâya girilen 1.465 glioma görüntüsünün 1.011'i eğitim, 291'i doğrulama ve 163'ü test; 714 meningioma görüntüsünün 510'u eğitim, 142'si doğrulama, 62'si test; 931 pituitary adenoma görüntüsünün 659'i eğitim, 185'i doğrulama, 87'si test olarak sınıflandırılmıştır. Yapay zeka modeli oluşturulurken her 8 örnekte bir yenileme ve 15 tekrar oranlarıyla çalıştırılmıştır. Bu rakamlar en yüksek teşhis doğruluğunu elde etmek için optimum oranda belirlenmiştir.

Model	Çözünürlük (piksel)	mAP (50-95)	Hız (ms)
YOLOv8n	640	%37,3	87.2
YOLOv8s	640	%44,9	131.6
YOLOv8m	640	%50,2	290.4
YOLOv8l	640	%52,9	412.1
YOLOv8x	640	%53,8	683.1

Şekil 11 – COCO setinde YOLOv8 algoritmasının başarımı

Algoritma, COCO (Common Objects in Context) setinde eğitildiğinde yüksek başarım sağlamaktadır. COCO, yapay zeka algoritmalarının karşılaştırmasında standart veri setidir. Konumlandırma modelinde hız-mAP bakımından en optimistik sonuçları YOLOv8x baz modeli vermiştir. Bu sonuçlar göz önüne alındığında YOLOv8n modelinin hızlı çıktı fakat düşük doğruluk oranları nedeniyle yalnızca sınıflandırma modelinde kullanılması uygun görülmüştür. Bu işlemler GPU veya XLINIX gibi yapay zeka özeli FPGA modüllerinde geliştirilirse daha hızlı ve tatminkâr sonuçlar verebilir. Projenin ilerleyen aşamalarında bu modüllerin kullanılması öngörülmektedir.

Etiketleme sürecinden elde edilen seçkin veriler konumlandırma modelinde kullanılmaktadır. Konumlandırma modellerinde lezyonun görüldüğü bölgenin apaçık ortada olması elzemdir. Sınıflandırma modelinin aksine konumlandırma modellerine elde edilen sonuçlarda lezyonun görüldüğü bölgenin nitelikleri kullanıcıya verilebilmektedir. Bu modelin eğitiminde kullanılan veriler teker teker uzman radyologlar gözetiminde teşhis edilmiş ve lezyon barındıran bütün görüntüler etiket verileriyle birlikte eğitim havuzuna eklenmiştir. Dönüm sayısı sınıflandırma modelinin aksine doğruluk oranını artırmak maksadıyla 50 olarak girilmiş ve işlem sürecinde “yolov8x” baz modeli kullanılmıştır.

Eğitim işlemi AMD Ryzen 5 5500U with Radeon Graphics, 2100 Mhz, 6 Çekirdek, 12 Mantıksal İşlemci ve 8,00 GB fiziksel bellek üzerinde gerçekleştirilmiş ve yukarıdaki değerlerle 19 saat 54 dakikada 8.11 it/s hızla gerçekleşmiştir. Yapay zekâ işleçleri olan bir bilgisayar kullanılması durumunda bu süreler indirgenebilmektedir. Modelin doğruluk düzeyinin optimum seviyelerde tutulması için baz model “yolov8x” olarak seçilmiştir. Eğitim işlemi PyTorch işlemci için derlenerek gerçekleştirilmiştir. Bu eğitim işlemini yavaşlatmış olsa da geçerli bir grafik birimi bulunmadığından böyle bir yola başvurulmuştur.

Proje İş-Zaman Çizelgesi

AYLAR						
İşin Tanımı	**Ağustos**	**Eylül**	**Ekim**	**Kasım**	**Aralık**	**Ocak**
Proje Koşullarının Tespiti	**X**					
Saha Çalışması		**X**				
Verilerin Toplanması, Analizi ve Yazılım			**X**	**X**		
Verilerin Pratikte Yeterliliğinin Tespiti					**X**	
Proje Raporu Yazımı						**X**

Bulgular

Sınıflandırma Modelinin Analizi

Çeşitli özel hastanelerin veri tabanındaki görüntülerin kullanıldığı sınıflandırma modelinin analizi sırasında elde edilen sonuçlar, tatminkâr bir doğruluk oranını ortaya koymaktadır. Bağımsız olarak seçilen görüntülerle gerçekleştirilen çalışmada, 100 görüntünün 99'u başarılı bir şekilde doğru teşhis edilmiştir. Bu yüksek doğruluk oranı, sınıflandırma modelinin güvenilirliğini ve etkinliğini vurgulamaktadır. Daha da önemlisi, elde edilen sonuçlar hastane radyologları tarafından titiz bir şekilde analiz edilmiş ve doğrulanmıştır. Radyologlar tarafından yapılan bu bağımsız analizler, sınıflandırma modelinin klinik teşhis konusundaki başarısını kesinleştirmiştir.

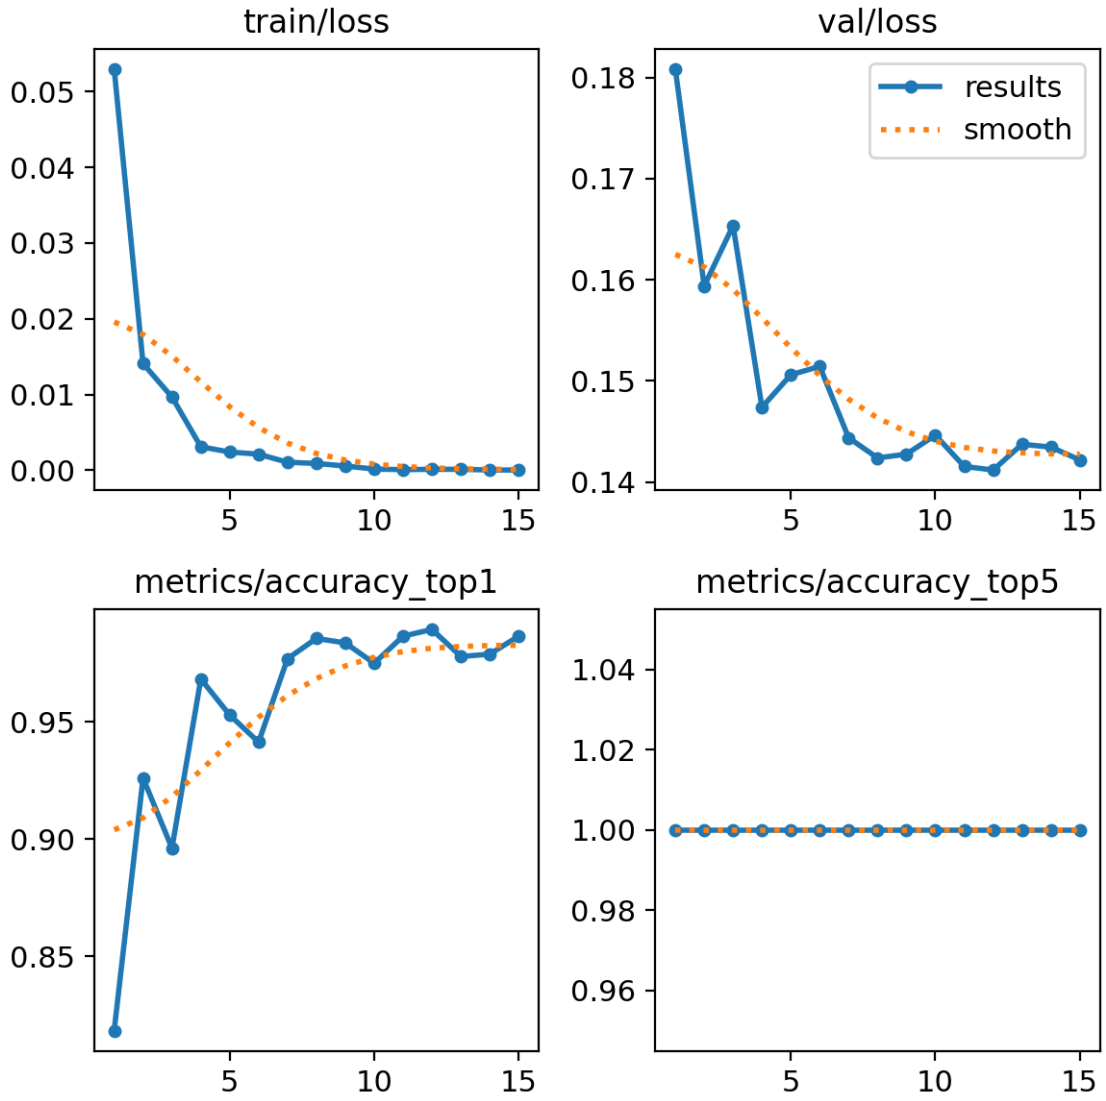

Şekil 11 – Sınıflandırma modelinin eğitim sürecinde çizilen grafikler

Sonuç olarak elde edilen verilerden yola çıkarak YOLOv8 dokümantasyonunda belirtilen yöntemlerle yapılan hesaplamalarda bu rakamlarla ve "yolov8n-cls" baz modeliyle algoritmanın sınıflandırma modunda oluşturulan modelin en düşük doğruluk oranının ilk dönümde %81,827 olup en iyi dönümde %98,654 olduğu saptanmıştır. Sonuç olarak ortalama %98'lik bir doğruluk oranından bahsedilmektedir. (Detaylı sonuçlar için bkz. EK-1)

Bu çalışmanın sonucunda ortaya çıkan yüksek doğruluk oranları, tıbbi alandaki uygulamalar için büyük bir potansiyeli işaret etmektedir. Sınıflandırma modelinin sunduğu güvenilir teşhisler, tıpta önemli bir değişime öncülük edebilir ve hastane ortamında daha etkili ve hızlı hasta yönetimini mümkün kılabilir. Bu başarı, yapay zekâ destekli modellerin klinik uygulamalardaki rolünü güçlendirecek ve sağlık sektöründe inovasyonun önünü açacaktır.

Konumlandırma Modelinin Analizi

Yapay zekâ algoritmasının çıktıları, çeşitli vakalarda titiz bir şekilde değerlendirildi. Elde edilen sonuçlar detaylı bir analize tabi tutularak, model dosyasının performansı üzerine kapsamlı bir inceleme yapıldı. Gözlemler neticesinde, algoritmanın doğruluk oranı ortaya çıkan görüntülerin yüzde 95'inde doğru teşhis yapma yeteneğini sergiledi. Bu başarı, özellikle mAP (ortalama doğruluk oranı) sonuçlarıyla benzer olup, algoritmanın geniş bir veri setinde sağlam bir performans sergiilediğini gösteriyor. Bu sonuçlar, yapay zekâ algoritmalarının klinik teşhislerde güvenilir bir yardımcı olarak potansiyelini vurgulamakta ve tıp alanındaki ilerlemelerde önemli bir adımı temsil etmektedir.

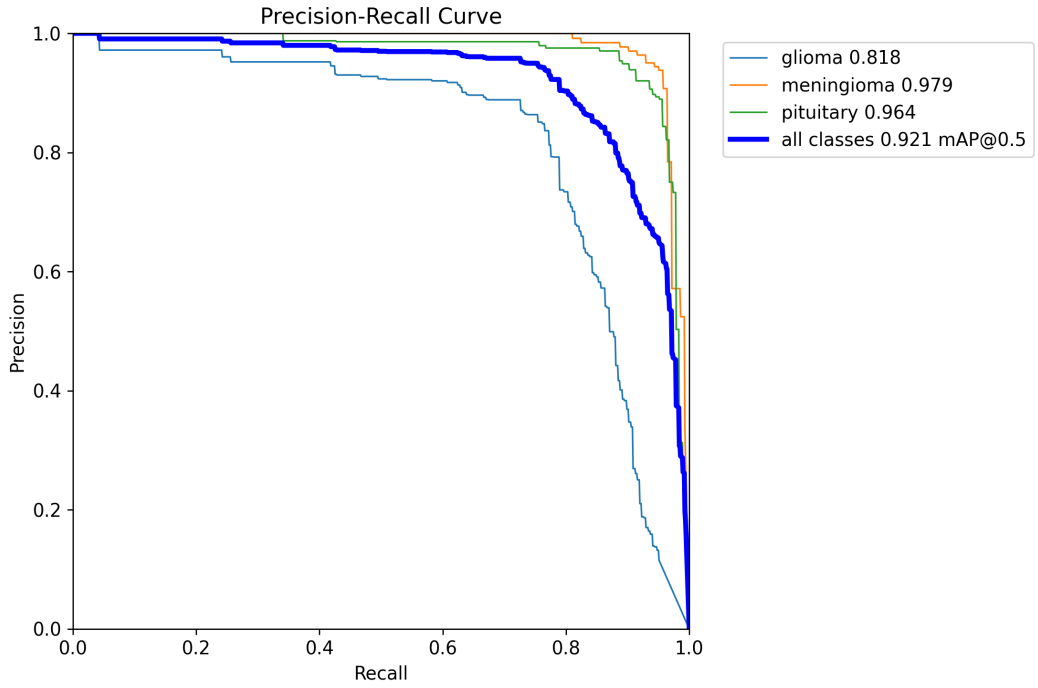

Şekil 11 – Hassasiyet-Çağrışım eğrisi

Algoritma'nın Çalışma Mantığı bölümünde açıklanan hesaplamalar yapıldığında eğitilen konumlandırma modelinin %92.1'lik bir mAP'yi yakaladığını görebiliriz. Elde edilen mAP değerleri hastanelerin PACS sistemleri üzerinde algoritmanın çıktı modelleri kullanılarak gözlenen doğruluk oranlarıyla örtüşmektedir. Daha kapsamlı hesaplamalar yapıldığında model hakkında her türlü yorum yapılabilir. (Detaylı sonuçlar için bkz. EK-2)

Sonuç ve Tartışma

Sonuç olarak elde edilen doğruluk oranları sektörde çalışan uzman radyologlara gösterilmiş ve farklı hastanelerin veri tabanlarında denenmiştir. Bu gözlem sonucunda sahada çalışan doktorlar projenin sürdürülebilirliğine ve geliştirilebilirliğine yeşil ışık yakmış ve yeni yapay zekâ algoritmalarının karmaşık teşhis sistemlerinde uygulanabilirliği kanıtlanmıştır.

İlerleyen süreçte projenin geliştirilmesi adına devlet hastanelerine başvurulabilir ve buralardan toplanan veriler doğrultusunda çok nadir görülse de Glioblastoma gibi kesin olarak can alan hastalıkların erken teşhisi, hastanın evveliyatıyla birlikte özel olarak oluşturulan yapay sinir ağlarıyla incelenerek gerçekleştirilebilir. Bu ancak çalışmanın akademik boyut kazanması ve gerekli izinlerin alınmasıyla gerçekleşebilir.

Öneriler

Yapay zekânın sağlık alanında kullanımıyla ilgili yapılan çalışmalar daha geniş imkanlarla farklı algoritmalar üzerinde denenmeli ve geniş bir grup istatistik çalışmasıyla optimum sonuca gidilmelidir. Projemiz tek kişilik bir çalışma olmasından dolayı toplu çalışma konusunda fazlasıyla sığ kalmıştır. Bu gibi projelerde grup halinde çalışılması gerekir. Detaylı iş bölümünün ve zaman çizelgesinin oluşturulması elzemdir.

Doktorlarla yapılan görüşmelerde konumlandırma modelinden ziyade sınıflandırma modelinin tümörün oluşum sürecinde gerçekleştirilen teşhislerde etkili olacağı belirtildi. Kayseri bölgesi özelinde yapılan analiz sürecinde devlet hastanelerine yeterli erişim iznimiz olmadığı için Glioblastoma'nın erken evrede teşhisine bu çalışmada yer verilememiştir. Lisansüstü çalışmalar üniversite hastaneleri tarafından kabul göreceği için bu çalışmada kullanılan veri setlerine ek olarak fakültelerin veri tabanları da eğitim sürecine dahil edilirse erken teşhis kaçınılmaz bir başarıma ulaşacaktır.

Kaynakça

Latif, G., Ben Brahim, G., Iskandar, D. N. E. A., Bashar, A. ve Alghazo, J. (2022). Glioma Tumors' Classification Using Deep-Neural-Network-Based Features with SVM Classifier. Multidisciplinary Digital Publishing Institute, https://doi.org/10.3390/diagnostics12041018

Anita, J. N. ve Kumaran, S. (2022). A Deep Learning Architecture for Meningioma Brain Tumor Detection and Segmentation, https://doi.org/10.15430/JCP.2022.27.3.192

Cheng, J., Yang, W., Huang, M., Huang, W., Jiang, J., Zhou, Y., vd. (2016). Retrieval of Brain Tumors by Adaptive Spatial Pooling and Fisher Vector Representation, http://dx.doi.org/10.6084/m9.figshare.1512427

Akalın, F. ve Yumuşak, N. (2022) "Detection and classification of white blood cells with an improved deep learning-based approach," Turkish Journal of Electrical Engineering and Computer Sciences: Vol. 30: No. 7, Article 16. https://doi.org/10.55730/1300-0632.3965

Dong, H., Yang, G., Liu, F., Mo, Y. ve Guo, Y. (2017). Automatic Brain Tumor Detection and Segmentation Using U-Net Based Fully Convolutional Networks, https://arxiv.org/pdf/1705.03820.pdf

Yousef, R., Khan, S., Gupta, G., Siddiqui, T., Albahlal, B. M., Alajlan, S. A., vd. (2023). U-Net-Based Models towards Optimal MR Brain Image Segmentation, https://doi.org/10.3390/diagnostics13091624

Paul, S., Ahad, T.. ve Hasan, M.,(2022). Brain Cancer Segmentation Using YOLOv5 Deep Neural Network, https://arxiv.org/ftp/arxiv/papers/2212/2212.13599.pdf

Arı, A. ve Hanbay, D. (2018) "Deep learning based brain tumor classification and detection system," Turkish Journal of Electrical Engineering and Computer Sciences: Vol. 26: No. 5, Article 9. https://doi.org/10.3906/elk-1801-8

Yan, W. Q. (2023). Computational Methods for Deep Learning: Theory, Algorithms, and Implementations (2nd Edition) Auckland University of Technology https://cerv.aut.ac.nz/wp-content/uploads/2023/06/Deep_Learning_Book.pdf

EK-1

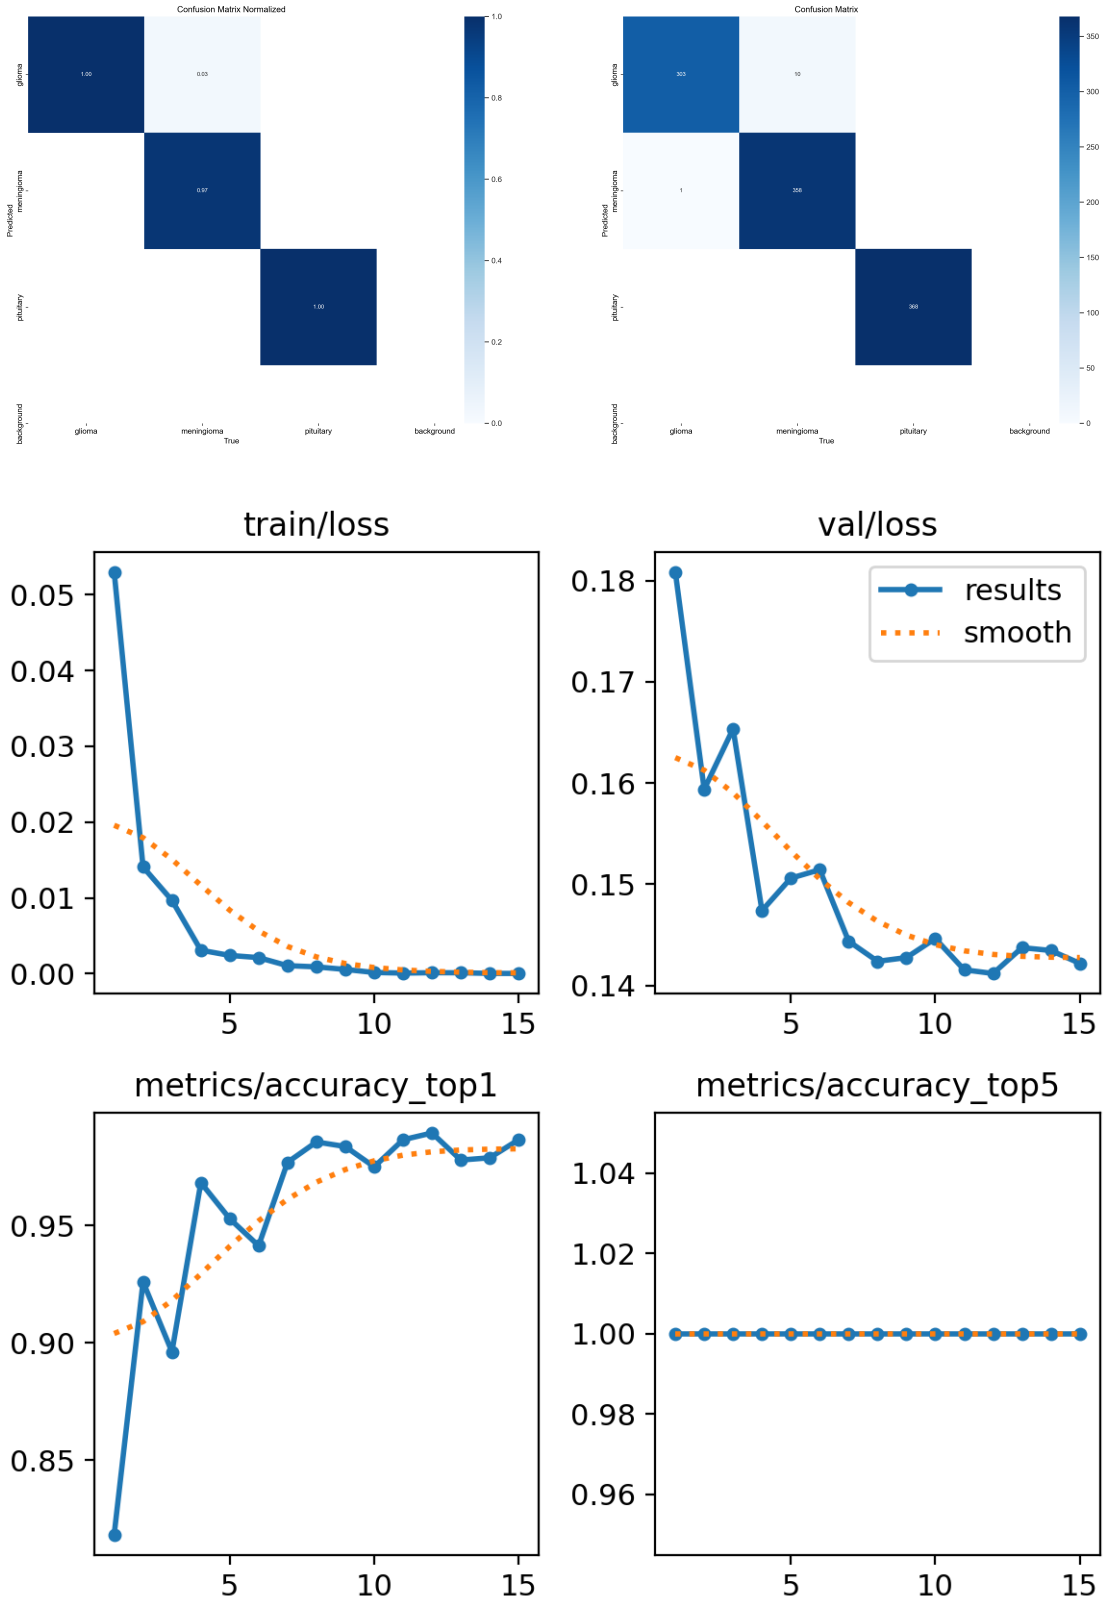

Yukarıdaki şekiller yapay zekâ algoritmasından çıkan eğitim bilgilerinin grafikleridir. Buna göre **Bulgular**'da açıklanan **Sınıflandırma Modelinin Eğitimi** sonucunda elde edilen modelin kayıp, hassasiyet ve veri kışım matris grafiği yukarıdaki gibidir.

EK-2

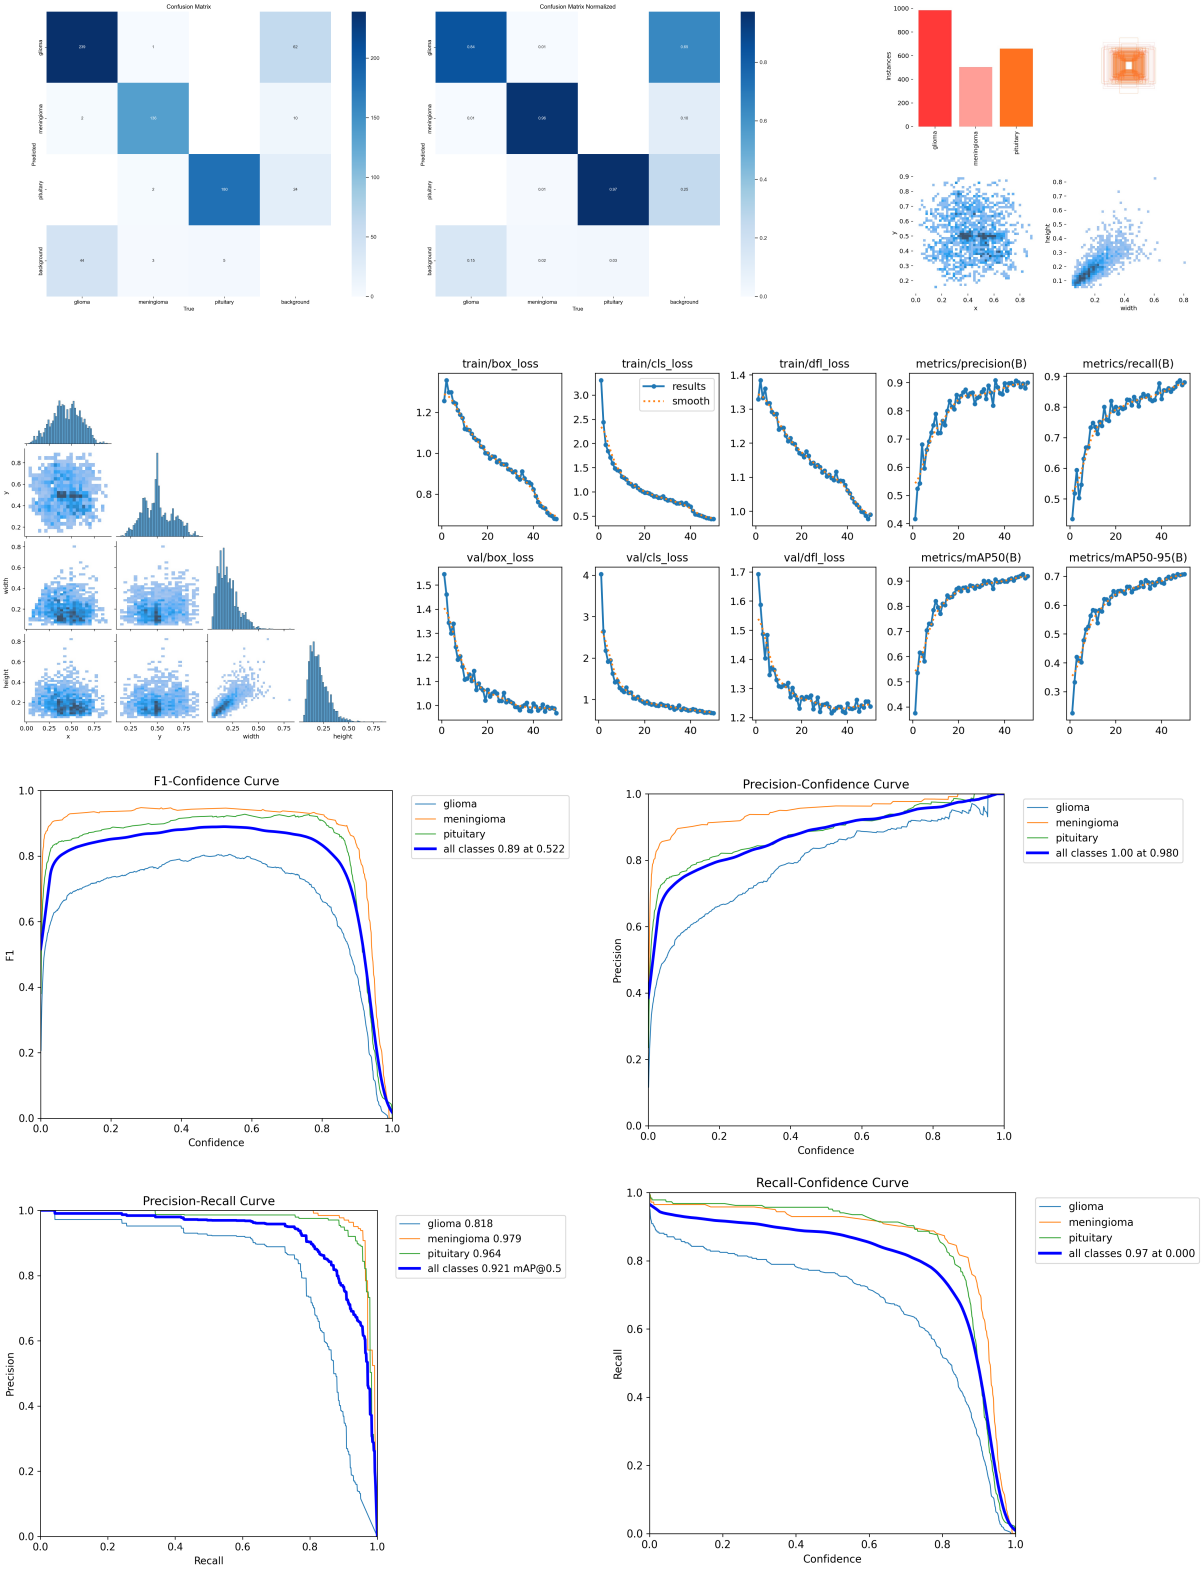

Bu eğrilerin tamamı yapay zekanın konumlandırma eğitiminden çıktı olarak alınan sonuçların verisidir. Detaylı analizler için kullanılabilir.